

Métodos Numéricos
4 de junio de 2018
Segundo Parcial



**DEPARTAMENTO
DE COMPUTACION**
Facultad de Ciencias Exactas y Naturales - UBA

<input type="checkbox"/> Resolver ejercicios en hojas separadas <input type="checkbox"/> Completar nombre en las hojas <input type="checkbox"/> Completar LU y nombre en el enunciado <input type="checkbox"/> Justificar <u>todas</u> las respuestas	Lib. Univ.		Nombre y Apellido		
	Ej. 1	Ej. 2	Ej. 3	Ej. 4	Nota
	23	30	23	22	98 (AP)

1. Sea $A \in \mathbb{R}^{n \times n}$ una matriz simétrica. Recordamos que el *cociente de Rayleigh* de un vector cualquiera $x \in \mathbb{R}^n$ es

$$r_A(x) = \frac{x^t A x}{x^t x}$$

- (a) Siendo $\rho(A)$ el radio espectral de A , probar que $\forall x \in \mathbb{R}^n, |r_A(x)| \leq \rho(A)$. (10 puntos)
 (b) Sea $y \in \mathbb{R}^n$ un autovector de A asociado al autovalor λ , tal que $\|y\|_2 = 1$ y $|\lambda| = \rho(A)$. Se dispone de una aproximación $z = y + h$ de y , con $z, h \in \mathbb{R}^n, \|z\|_2 = 1$ que verifica $\|z - y\|_2 = \|h\|_2 < \epsilon$ con $\epsilon \in \mathbb{R}_{>0}$. Probar que si $M = \|A - \lambda I\|_2$, se tiene: (15 puntos)

$$|r_A(z) - \lambda| \leq M^2 \epsilon^2$$

2. Sea $A \in \mathbb{R}^{n \times n}$ una matriz tal que $rg(A) = r > 1$ y $A = U \Sigma V^t$ su descomposición SVD. Sean además u_1, \dots, u_n las columnas de U , v_1, \dots, v_n las columnas de V , y $\sigma_1, \dots, \sigma_r$ sus valores singulares no nulos. Siendo $B = A - \sigma_1 u_1 v_1^t$, probar:

- (a) $v_1 \in Nu(B)$. (5 puntos)
 (b) $Bw = Aw$ para todo vector w ortogonal a v_1 . (5 puntos)
 (c) $\sigma_2, \dots, \sigma_r$ son valores singulares de B . (10 puntos)
 (d) Los vectores v_2, \dots, v_r se encuentran en el espacio fila de B . (10 puntos)

3. Sea $A \in \mathbb{R}^{n \times n}$ definida positiva y $\omega > 0$ una constante. Sea $D \in \mathbb{R}^{n \times n}$ la matriz diagonal cuyos elementos son los elementos de la diagonal de A . Se tiene el siguiente esquema iterativo:

$$x^{(k+1)} = x^{(k)} + \omega D^{-1} r^{(k)} \quad k = 0, 1, \dots$$

con $r^{(k)} = b - Ax^{(k)}$ el residuo de la iteración k -ésima.

- (a) Probar que si $\omega = 1$ el esquema iterativo se corresponde al método de Jacobi. (10 puntos)
 (b) Sea $A = \begin{pmatrix} 1 & \alpha \\ 0 & 1 \end{pmatrix}$ y $\alpha \in \mathbb{R}$. Probar que el esquema iterativo converge si y sólo si $\omega < 2$. (13 puntos)
4. Sea $k \in \mathbb{R}$ y $C = \{(1, 0), (0, k), (-1, 1)\}$ un conjunto de puntos en \mathbb{R}^2 .
- (a) Hallar la recta que pasa por el origen y es la más cercana en el sentido de cuadrados mínimos al conjunto de puntos C . Mostrar que dicha recta no depende de k . (12 puntos)
 (b) Calcular el error cometido en la aproximación de cuadrados mínimos. ¿Para qué valor de k el error es mínimo? Explicar por qué siendo que cuadrados mínimos minimiza el error cometido y éste depende de k , la solución hallada en (a) no depende de k . (10 puntos)

1) Sea $x \in \mathbb{R}^n$ y $A \in \mathbb{R}^{n \times n}$ una matriz simétrica, el coeficiente de Rayleigh de x es de la forma: $r_A(x) = \frac{x^T A x}{x^T x}$

a) Como A es simétrica tiene una base ortonormal de autovectores de la forma $\{x_1, \dots, x_n\}$. Con ellos vamos que podemos escribir a x como combinación lineal de los vectores de la forma $x = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n$. Recordamos que el autovector asociado a x_i es λ_i .

En base a esto: $|r_A(x)| = \left| \frac{x^T A x}{x^T x} \right| = \left| \frac{(\alpha_1 x_1^T + \alpha_2 x_2^T + \dots + \alpha_n x_n^T) A (\alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n)}{(\alpha_1 x_1^T + \alpha_2 x_2^T + \dots + \alpha_n x_n^T) (\alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n)} \right| = \left| \frac{\left(\sum_{i=1}^n \alpha_i x_i^T \right) A \left(\sum_{i=1}^n \alpha_i x_i \right)}{\left(\sum_{i=1}^n \alpha_i x_i^T \right) \left(\sum_{i=1}^n \alpha_i x_i \right)} \right|$

$$= \left| \frac{\left(\sum_{i=1}^n \alpha_i x_i^T \right) \left(\sum_{i=1}^n \alpha_i A x_i \right)}{\left(\sum_{i=1}^n \alpha_i x_i^T \right) \left(\sum_{i=1}^n \alpha_i x_i \right)} \right| = \left| \frac{\left(\sum_{i=1}^n \alpha_i x_i^T \right) \left(\sum_{i=1}^n \alpha_i \lambda_i x_i \right)}{\left(\sum_{i=1}^n \alpha_i x_i^T \right) \left(\sum_{i=1}^n \alpha_i x_i \right)} \right| \quad (A x_i = \lambda_i x_i)$$

$$= \left| \frac{\sum_{i=1}^n \lambda_i \alpha_i^2 x_i^T x_i}{\sum_{i=1}^n \alpha_i^2 x_i^T x_i} \right| \quad (\{x_1, \dots, x_n\} \text{ forman una base ortonormal, } x_i^T x_j = \delta_{ij})$$

el paréntesis mejor escribirlo debajo del \leq

por lo que $x_i^T x_j = 0$ si $i \neq j$ y $x_i^T x_i = 1 \Rightarrow \left| \frac{\sum_{i=1}^n \lambda_i \alpha_i^2}{\sum_{i=1}^n \alpha_i^2} \right| \leq \max_{\lambda \text{ autovector de } A} |\lambda| \Rightarrow \lambda_i \leq |\lambda_i| \leq \rho(A)$ para todo $i = 1, \dots, n$.

$= \rho(A) \frac{\sum_{i=1}^n \alpha_i^2}{\sum_{i=1}^n \alpha_i^2} = \rho(A)$

OJO, no puedes acotar de esa manera sin decir eso que $\left| \frac{\sum \lambda_i \alpha_i^2}{\sum \alpha_i^2} \right| \leq \frac{\sum |\lambda_i| \alpha_i^2}{\sum \alpha_i^2}$

\therefore Para todo $x \in \mathbb{R}^n$, $|r_A(x)| \leq \rho(A)$

b) Sea $y \in \mathbb{R}^n$ tal que $Ay = \lambda y$, $\|y\|_2 = 1$ y $|\lambda| = \rho(A)$. Sea $z = y + h$ con $z, h \in \mathbb{R}^n$, $\|z\|_2 = 1$ y $\|z - y\|_2 = \|h\|_2 \leq \epsilon$ con $\epsilon > 0$

Sea $M = \|A - \lambda I\|_2$ o sea $|r_A(z) - \lambda| \leq M \epsilon^2$. Para ello vamos que:

$$|r_A(z) - \lambda| = \left| \frac{z^T A z}{z^T z} - \lambda \right| = \left| \frac{z^T A z - \lambda z^T z}{z^T z} \right| = \left| \frac{z^T (A - \lambda I) z}{z^T z} \right| = \left| \frac{(y+h)^T (A - \lambda I) (y+h)}{(y+h)^T (y+h)} \right|$$

$$= \left| \frac{y^T A y - \lambda y^T y + y^T A h - \lambda y^T h + h^T A y - \lambda h^T h}{y^T y + 2y^T h + h^T h} \right|$$

(y es autovector de A con autovector λ) $= \left| \frac{y^T A h - \lambda y^T h + h^T A y - \lambda h^T h}{y^T y + 2y^T h + h^T h} \right|$

$$= \left| \frac{y^T A h - \lambda y^T h + h^T A y - \lambda h^T h}{y^T y + 2y^T h + h^T h} \right|$$

($y^T A h \in \mathbb{R} \Rightarrow y^T A h = (y^T A h)^T = h^T A^T y = h^T A y$ pues $A = A^T$) $= \left| \frac{h^T A y - \lambda h^T h}{y^T y + 2y^T h + h^T h} \right| = \left| \frac{h^T (A - \lambda I) h}{y^T y + 2y^T h + h^T h} \right| \leq$

$$\leq \|h\|_2 \| (A - \lambda I) h \|_2 \quad (\text{desigualdad de C-S}) \leq \|h\|_2 \|A - \lambda I\|_2 \|h\|_2 \quad (\text{propiedad de norma inducida}) \leq \epsilon \cdot M \cdot \epsilon = M \epsilon^2$$

super prolijo

2) Sea $A \in \mathbb{R}^{n \times n}$ tal que $\text{rg}(A) = r > 1$ y $A = U \Sigma V^t$ su descomposición SVD tal que $U = (u_1 \dots u_n)$, $V = (v_1 \dots v_n)$ y $\Sigma = \begin{pmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{pmatrix}$ con $\sigma_i > 0$ para todo $i=1, \dots, r$. Sea $B = A - \sigma_1 u_1 v_1^t$

a) Queremos ver que $v_1 \in \text{Nul}(B)$, es decir, $B v_1 = 0$. Para ello hacemos:

$$B v_1 = (A - \sigma_1 u_1 v_1^t) v_1 = A v_1 - \underbrace{\sigma_1 u_1 v_1^t v_1}_{\|v_1\|_2=1} = U \Sigma V^t v_1 - \sigma_1 u_1 = U \Sigma e_1 - \sigma_1 u_1 \left(V^t = \begin{pmatrix} v_1^t \\ \vdots \\ v_n^t \end{pmatrix} \Rightarrow V^t v_1 = \begin{pmatrix} v_1^t v_1 \\ \vdots \\ v_n^t v_1 \end{pmatrix} = \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} = e_1 \right)$$

per ser V ortogonal y entonces sus columnas forman una base ortogonal) $= U \sigma_1 e_1 - \sigma_1 u_1 = \sigma_1 (\text{col}_1(U) - u_1) = \sigma_1 u_1 - \sigma_1 u_1 = 0 \checkmark \therefore B v_1 = 0 \Rightarrow v_1 \in \text{Nul}(B)$

b) Sea $w \in \mathbb{R}^n$ tal que $w \perp v_1$, vemos que $w^t v_1 = v_1^t w = 0$ y tenemos que

$$B w = (A - \sigma_1 u_1 v_1^t) w = A w - \underbrace{\sigma_1 u_1 v_1^t w}_0 = A w$$

c) Mando $B = A - \sigma_1 u_1 v_1^t$ vemos que $B^t B = (A - \sigma_1 u_1 v_1^t)^t (A - \sigma_1 u_1 v_1^t) = (A^t - \sigma_1 v_1 u_1^t) (A - \sigma_1 u_1 v_1^t) = A^t A - \sigma_1 v_1 u_1^t A - A^t \sigma_1 u_1 v_1^t + \sigma_1^2 v_1 u_1^t u_1 v_1^t = A^t A - \sigma_1 v_1 u_1^t U \Sigma V^t - V \Sigma^t U^t \sigma_1 u_1 v_1^t + \sigma_1^2 v_1 v_1^t = A^t A - \sigma_1 v_1 e_1^t \Sigma V^t - V \Sigma e_1 \sigma_1 u_1^t + \sigma_1^2 v_1 v_1^t$

$$(u_1^t U = u_1^t (u_1 \dots u_n) = (1 \ 0 \dots 0) = e_1^t \Rightarrow U^t u_1 = e_1) = A^t A - \sigma_1^2 v_1 e_1^t V^t - v_1 \sigma_1^2 v_1^t + \sigma_1^2 v_1 v_1^t \left(\Sigma e_1 = \begin{pmatrix} \sigma_1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} = \sigma_1 e_1 \right) = A^t A - \sigma_1^2 v_1 v_1^t - v_1 v_1^t \sigma_1^2 + \sigma_1^2 v_1 v_1^t \left(V e_1 = v_1 \Rightarrow (V e_1)^t = e_1^t V^t = v_1^t \right) = A^t A - v_1 v_1^t \sigma_1^2$$

Obra, los autovalores de $B^t B$ son los cuadrados de los valores singulares de B . En base a eso vemos que si tomamos v_i con $i=2, \dots, r$ obtenemos:

$$B^t B v_i = (A^t A - v_1 v_1^t \sigma_1^2) v_i = A^t A v_i - \underbrace{\sigma_1^2 v_1 v_1^t v_i}_0 = \sigma_1^2 v_i \left(v_1^t v_i = 0 \text{ por } i \neq 1 \text{ y } A^t A v_i = \sigma_i^2 v_i \text{ para todo } i=1, \dots, r \right)$$

Por ende v_i es autovector de $B^t B$ con autovalor σ_i^2 para $i=2, \dots, r$. Esto nos dice que $\sigma_2, \dots, \sigma_r$ son valores singulares de B

$$(\sqrt{\sigma_2^2}, \dots, \sqrt{\sigma_r^2} = |\sigma_2|, \dots, |\sigma_r| = \sigma_2, \dots, \sigma_r \text{ por ser } \sigma_i > 0 \text{ para todo } i=1, \dots, r)$$

d) El espacio fila de B se encuentra formado por el subespacio de \mathbb{R}^n de la forma $\langle \text{fil}_1(B), \dots, \text{fil}_n(B) \rangle$. Sabiendo que el espacio columna de B es $\text{Im}(B)$ (Para $x \in \mathbb{R}^n$, $B x = \begin{pmatrix} c_1 & \dots & c_n \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = c_1 x_1 + \dots + c_n x_n$) vemos que si tomamos B^t las columnas de B^t son las filas de B y luego el espacio fila de B es $\text{Im}(B^t)$.

Obra con eso en mente tomamos el vector $y_i = \frac{u_i}{\sigma_i}$ donde $i \in \{2, \dots, r\} \Rightarrow \sigma_i > 0$ y $u_i \neq 0$ y vemos que:

$$B^t y_i = (A - \sigma_1 u_1 v_1^t)^t \frac{u_i}{\sigma_i} = (A^t - \sigma_1 v_1 u_1^t) \frac{u_i}{\sigma_i} = \frac{A^t u_i}{\sigma_i} - \frac{\sigma_1 v_1 u_1^t u_i}{\sigma_i} = (U \Sigma V^t)^t \frac{u_i}{\sigma_i} = V \Sigma^t U^t \frac{u_i}{\sigma_i} = V \Sigma^t e_i = V e_i \frac{1}{\sigma_i} = v_i$$

Con esto vemos que para todo v_i con $i=2, \dots, r$ existe $y_i \in \mathbb{R}^n$ tal que $B^t y_i = v_i \Rightarrow v_2, \dots, v_n$ pertenecen al espacio fila de B

IMPEDIBLE

3) Sea $A \in \mathbb{R}^{n \times n}$ definida positiva, $w > 0$ y $D \in \mathbb{R}^{n \times n}$ la matriz diagonal con los elementos de la diagonal de A tenemos el esquema iterativo: $x^{(k+1)} = x^{(k)} + w D^{-1} r^{(k)}$ para $k=0,1,\dots$ siendo $r^{(k)} = b - Ax^{(k)}$

a) $D^{-1} \in \mathbb{R}^{n \times n}$ existe pues al ser A definido positivo los elementos de su diagonal son positivos ($e_i^T A e_i = a_{ii} > 0$ para todo $i=1,\dots,n$)

Siendo $w=1$ vemos que podemos escribir el esquema iterativo como:

$$x^{(k+1)} = x^{(k)} + D^{-1} r^{(k)} = x^{(k)} + D^{-1} (b - Ax^{(k)}) = \underline{x^{(k)} + D^{-1} b - D^{-1} A x^{(k)}}$$

Otro, tomando el splitting de $A = D' - L - U$ donde D' es diagonal, L es estrictamente triangular inferior y U es estrictamente triangular superior vemos que $D' = D$, entonces:

Siendo $w=1$ vemos que podemos escribir el esquema iterativo como:

$$x^{(k+1)} = x^{(k)} + D^{-1} b - D^{-1} (D - L - U) x^{(k)} = x^{(k)} + D^{-1} b - \underbrace{D^{-1} D}_{I} x^{(k)} + D^{-1} L x^{(k)} + D^{-1} U x^{(k)} = x^{(k)} - x^{(k)} + D^{-1} (L + U) x^{(k)} + D^{-1} b =$$

$$= \underline{D^{-1} (L + U) x^{(k)} + D^{-1} b} = \underline{T_J x^{(k)} + c_J}$$
 donde T_J es la matriz de iteración del método de Jacobi y c_J su constante correspondiente

b) Sea $A = \begin{pmatrix} 1 & \alpha \\ 0 & 1 \end{pmatrix}$ con $\alpha \in \mathbb{R}$ queremos que el método iterativo converja. Para ello vemos que la matriz del método iterativo es T :

$$x^{(k+1)} = x^{(k)} + w D^{-1} r^{(k)} = x^{(k)} + w D^{-1} (b - Ax^{(k)}) = x^{(k)} + w D^{-1} b - w D^{-1} A x^{(k)} = (I - w D^{-1} A) x^{(k)} + w D^{-1} b \Rightarrow \underline{T = I - w D^{-1} A}$$

$$\text{Siendo } A = \begin{pmatrix} 1 & \alpha \\ 0 & 1 \end{pmatrix} \text{ podemos calcular } D = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \Rightarrow D^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = I_2 \text{ y entonces } T = I - w \underbrace{D^{-1} A}_I = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} - w \begin{pmatrix} 1 & \alpha \\ 0 & 1 \end{pmatrix} = \underline{\begin{pmatrix} 1-w & -\alpha w \\ 0 & 1-w \end{pmatrix}}$$

Otro, el método converge sii $\rho(T) < 1$ por lo que si vemos el polinomio característico de T llegamos a que

$$P_T(\lambda) = \det(T - \lambda I) = \det \begin{pmatrix} 1-w-\lambda & -\alpha w \\ 0 & 1-w-\lambda \end{pmatrix} = (1-w-\lambda)^2 - \alpha \cdot 0 = 0 \Rightarrow (1-w-\lambda)^2 = 0 \text{ por lo que tenemos los autovalores:}$$

$$1-w-\lambda_1 = 0 \Rightarrow \lambda_1 = 1-w \text{ y } 1-w-\lambda_2 = 0 \Rightarrow \underline{\lambda_2 = 1-w = \lambda_1}$$

$$\text{Con esto vemos que } \rho(T) = \max\{|\lambda_1|, |\lambda_2|\} = \max\{|1-w|, |1-w|\} = \underline{|1-w|} \text{ y luego } \rho(T) < 1 \Leftrightarrow |1-w| < 1 \Leftrightarrow -1 < 1-w < 1 \Leftrightarrow$$

$$\Leftrightarrow -2 < -w < 0 \Leftrightarrow 0 < w < 2 \Leftrightarrow \underline{w < 2} \text{ (} w > 0 \text{)}$$

\therefore El esquema iterativo converge sii $w < 2$

4) Sea $k \in \mathbb{R}$ y $C = \{(1,0), (0,k), (-1,1)\} \in \mathbb{R}^2$

a) Buscamos $a \in \mathbb{R}$ tal que para $F(x) = ax$ se tiene el conjunto de cuadrados mínimos $\min_a \sum_{i=1}^3 (F(x_i) - y_i)^2$ donde $(x_i, y_i) \in C$

Esto se traduce a buscar el mínimo de la función $g(a) = \sum_{i=1}^3 (ax_i - y_i)^2$ para lo cual lo derivamos por a y vemos que:

$$\frac{\partial g}{\partial a}(a) = \sum_{i=1}^3 2(ax_i - y_i)x_i \text{ y para hallar un punto crítico tomamos } \frac{\partial g}{\partial a}(a) = 0 = \sum_{i=1}^3 2(ax_i - y_i)x_i = 2(a \cdot 1 - 0) \cdot 1 + 2(a \cdot 0 - k) \cdot 0 + 2(a \cdot (-1) - 1) \cdot (-1) = 2a + 0 + 2a + 2 = 4a + 2 \Rightarrow 4a = -2 \Rightarrow a = -\frac{1}{2}$$

Además calculamos $\frac{\partial^2 g}{\partial a^2}(a) = \sum_{i=1}^3 2x_i^2 = (1)^2 + 0^2 + (-1)^2 = 2 > 0$ y vemos que particularmente $\frac{\partial^2 g}{\partial a^2}(-1/2) > 0$ por lo que $a = -1/2$ mínimo g

y la recta que más se acerca a C en el sentido de cuadrados mínimos es $F(x) = -\frac{1}{2}x$ siendo que pasa por el origen.

Como podemos ver, dicho valor de a no depende de k ni lo hace la recta correspondiente.

b) Haciendo $F(x) = ax = -\frac{1}{2}x$ del ítem anterior, podemos calcular el error cometido por cuadrados mínimos como:

$$E = \sum_{i=1}^3 (F(x_i) - y_i)^2 = \left(-\frac{1}{2}x_1 - y_1\right)^2 + \left(-\frac{1}{2}x_2 - y_2\right)^2 + \left(-\frac{1}{2}x_3 - y_3\right)^2 = \left(-\frac{1}{2}\right)^2 + (-k)^2 + \left(-\frac{1}{2} - \frac{1}{2}\right)^2 = \frac{1}{4} + k^2$$

Como podemos ver, el error cuadrático depende del valor de $k \in \mathbb{R}$ en la segunda coordenada del segundo punto de C . Haciendo en su caso

vemos que $E(k) = \frac{1}{4} + k^2$ se minimiza para $k=0$ pues $\frac{\partial E}{\partial k}(k) = 2k = 0 \Rightarrow k=0$ y $\frac{\partial^2 E}{\partial k^2}(k) = 2 > 0$.

Esto parece tener sentido puesto que la recta que debíamos hallar para pasar por el origen, es decir, por el punto $(0,0)$ y este forma parte de C si $k=0$. Ahora, notamos que el error depende de k pero la solución de la recta hallada en a) no lo hace.


Esto podemos explicarlo viendo que para una recta genérica $F(x) = ax$ que pasa por el origen el error cometido es

$$E(k) = \sum_{i=1}^3 (F(x_i) - y_i)^2 = (ax_1 - y_1)^2 + (ax_2 - y_2)^2 + (ax_3 - y_3)^2 = (a \cdot 0)^2 + (0 - k)^2 + (a - 1)^2 = a^2 + k^2 + (a-1)^2$$

donde si miramos el término $(a-1)^2$ que es el error producido para el punto $(0,k)$ este no depende del valor de a sino del de k . Por

lo tanto, como buscamos el coeficiente a que minimice $E(k)$ sin alterar el valor de k , dicho error se va a cometer de igual magnitud

para toda recta que pase por el origen que sea de la forma $y = ax$ con $a \in \mathbb{R}$. Gráficamente vemos:



Para los diferentes valores de $a \in \mathbb{R}$ las rectas formadas pasan por $(0,0)$ por lo que el error

cometido por cuadrados mínimos con respecto a $(0,k)$ se toma siempre del origen como el área del cuadrado E de la figura.

El gráfico a su vez nos muestra la representación gráfica de $E(k)$ para $a = 1/2$ que es el coeficiente de la recta que lo minimiza.

Muy bien!